

回転子慣性の変動に対応したブラシレス DC モータの位置制御その 3 Position Control of a Brushless DC Motor Considering Variation of Rotor Inertia Ⅲ

○齋藤寛之*, 秋山宜万*, 松尾健史*, 三浦 武*, 谷口敏幸*, 米田 真**

○Hiroyuki Saito*, Yoshikazu Akiyama*, Kenshi Matsuo *, Takeshi Miura*, Toshiyuki Taniguchi*,
Makoto Yoneda**

*秋田大学, **オリエンタルモーター

*Akita University, **Oriental Motor Co., Ltd.

キーワード：ブラシレス DC モータ (brushless DC motor), 位置制御 (position control), 慣性負荷 (inertial load), ニューラルネットワーク (neural network), 可変ゲイン (variable gain)

連絡先：〒010-8502 秋田県秋田市手形学園町 1-1 秋田大学工学資源学部 電気電子工学科
三浦 武, TEL : (018)889-2329, FAX : (018)837-0406, E-mail : miura@ipc.akita-u.ac.jp

1. はじめに

ブラシレス DC モータはブラシ付 DC モータのような機械的整流機構を有していないため、保守が容易、ノイズレスであるなどの特徴を持つことから家電機器や OA 機器などに幅広く使用されている。また、近年では位置決め制御に対して高精度化、高速化といった厳しい制御仕様が要求されており、特に負荷変動に対するロバスト性が重要視されている。負荷変動は整定時間の増大や目標値追従性の悪化につながるため、これに対して制御器のゲインを変えるといった対策が必要となる。

文献 1)においては、負荷変動によって位置指令に対する応答が遅れてしまうという

問題に対して、フィードバック制御とフィードフォワード制御を組み合わせたシステムを構築することにより、目標値追従性を改善している。しかし、この方法ではゲイン調整を手動で行わなければならない。そこで、何らかの方法で制御期間中に負荷の慣性モーメントの値を取得することができれば、その値を用いて制御器のゲインを自動で調整することにより制御特性が改善できると考えられる。

負荷の慣性モーメントの同定方法については、文献 2), 3)によりニューラルネットワークを用いた方法が検討されている。特に、文献 3)によるとニューラルネットワークの入力に電流と回転速度を組み合わせたものを用いることにより精度の高い同定が

可能であると報告されている。

そこで、本研究では文献 3)により考案されたニューラルネットワークを用いて慣性モーメントの値を取得し、その値に応じて制御器のゲインを可変にするシステムを構築し、その有効性について検討した。

2. 実験装置の構成

本研究は図 1 に示す実験システムを用いて行った。供試モータはオリエンタルモーター社製のブラシレス DC モータ (DXMS2020-AA)で、定格電流 2.7[A]、定格回転速度 3000[min^{-1}]である。

位置制御系および速度制御系の処理はパーソナルコンピュータ PC1 を用いたソフトウェア制御によって行われ、トルク指令が D/A 変換器を介して駆動システムに入力される。このトルク指令に従って、駆動システム内で PWM 方式の電流制御が行われ、励磁電流を各相に流し、モータが駆動される。また、モータの回転角度はロータリーエンコーダによって検出され、駆動システムとアップ/ダウンカウンタボードを介して 1800[pulse/rev.]の信号として PC1 に入力される。

パーソナルコンピュータ PC2 には、市販のサーボ支援ソフトがインストールされており、駆動システム内のパラメータの読み出しと書き込みを行う。本研究では、このパラメータを工場出荷時のままで使用している。なお、PC2 は制御期間中には使用されない。また、本研究における入出力データのサンプリング時間は 1.0[ms]である。




図 1 実験システム

Fig.1 Experimental system.

3. 位置制御系と位置指令

本研究において基本となる位置制御系のブロック線図を図 2 に示す。位置制御器に P 制御、速度制御器に PI 制御を用いている。ここで、 θ_r : 目標指令位置、 θ : 回転子位置、 e_θ : 位置偏差、 ω_r : 目標指令速度、 ω : 回転速度、 e_ω : 速度偏差、 T_e : 発生トルク、 K_{pp} : 位置比例ゲイン、 K_{sp} : 速度比例ゲイン、 K_{si} : 速度積分ゲイン、 J : 回転子の慣性モーメントである。

また、位置制御器と速度制御器は次式により表される。

$$G_p(s) = K_{pp} = 50 \quad (1)$$

$$G_s(s) = \frac{K_{sp}s + K_{si}}{s} = \frac{0.00685s + 0.02}{s} \quad (2)$$

位置制御器の比例ゲイン K_{pp} と速度制御器の積分ゲイン K_{si} は、工場出荷時の駆動システムの制御パラメータを使用している。また、速度制御器の比例ゲイン K_{sp} は駆動システムの制御機能をパルス列指令による位置制御と設定したときに得られる応答波形に、本研究で構成した位置制御系による応答波形が近づくように決定されている。

位置指令は図 3 に示すように速度プロファイルを台形波状に与え、それを時間積分することにより得られる波形を用いる。このプロファイルは PTP(Point-to-Point)方式の位置決め用いられるものである⁴⁾。こ

の図において、0 から t_1 までの間(t_r)および t_2 から t_3 までの間(t_r)は加速および減速に要する期間である。 t_1 から t_2 までの間はモータが一定速度 ω_{cs} で回転する。ここで、 θ_0 : 最終停止位置、 t_r : 加減速期間、 t_{cs} : 一定速度期間である。




図2 位置制御系のブロック線図

Fig.2 Block diagram of position control system.




図3 角度目標値の時間変化プロファイル

Fig.3 Profile of temporal variation of the reference angle.

4. ニューラルネットワークの構造と学習

本研究で用いたニューラルネットワークの構造を以下に示す。これは、文献 3)によって構築されたものである。本研究で用いたニューラルネットワークは図 4 に示すように中間層を 1 層とした階層構造ニューラ

ルネットワークである⁵⁾。図に示すように、ニューラルネットワークには電流に定数 a ($=1/0.21$)を掛けた $a \cdot i$ 、回転速度を定格回転速度で割り規格化した ω_r/ω_{rR} を入力として用いており、サンプリング時間 $\Delta t(=1.0[\text{ms}])$ 毎に負荷の慣性モーメントの値が逐次出力されるようになっている。なお、 a はトルク指令を電圧に換算するための値である。

入力層におけるユニット数は電流と回転速度の時系列データの総数と等しくなるため、むやみに多くすることは避けなければならない。そのため、試行錯誤により 40[ms]分の時系列データをニューラルネットワークの入力としている。具体的に、入力層にはモータに位置指令を与えたときの応答時における電流と回転速度をそれぞれ $N=40$ 個ずつ取得し、これを入力としている。従って、入力層のユニット数は 80 個となる。また、中間層のユニット数は学習が安定に行われることを考慮して若干の試行錯誤により 10 個としている。

入力層の各ユニットでは具体的な演算が行われず、中間層の各ユニットへの入力の分配のみを行う。また、中間層にはシグモイド関数を用い、出力層には線形関数を用いている。各ユニット間における結合荷重はあらかじめ取得されたデータを教師データとした教師あり学習によって決定される。このオフライン学習には、慣性項を付加した back propagation 法⁶⁾を用いている。

また、本研究ではモータの回転子に慣性負荷を取り付けることにより、慣性モーメントを変化させた。実際に用いた慣性モーメントの値を表 1 に示す。ここで、load2 は無負荷の場合の 5 倍程度、load3 は 10 倍程度の慣性モーメントとなっており、教師デ

ータ取得時に用いた負荷である。load4 は load2 と load3 の間の慣性モーメントであり、ニューラルネットワークの汎化能力を確認するために用いる。

また、ニューラルネットワークは学習に使用する教師データの種類が少なく、かつ汎化能力が高いことが望ましい。よって、どのような駆動条件化での教師データを学習させれば汎化能力が高くなるのか検討する必要がある。教師データ取得時の駆動条件については表 1 に示した負荷条件以外に図 3 に示した位置指令を変えることが考えられる。そして、位置指令については一定速度時の速度指令 ω_{cs} 、または加減速期間 t_r を変えることが考えられる。文献 3) では、一定速度時の速度指令 ω_{cs} と加減速期間 t_r を両方とも変化させて学習させている。しかし、どのような駆動条件化での教師データを学習させれば汎化能力が高くなるのか調べるためには、一定速度時の速度指令 ω_{cs} と加減速期間 t_r の片方のみを変化させた方がよいと考えられる。よって、本研究では予備実験として一定速度時の速度指令 ω_{cs} のみを変化させた場合と、加減速期間 t_r のみを変化させた場合、そして両方を変化させた場合における教師データを学習させ、それぞれの汎化能力について調べた。

その結果、一定速度時の速度指令 ω_{cs} のみを変化させた場合、教師データの種類が少なく、かつ汎化能力が高いニューラルネットワークが構築できるという結果が得られた。そのため、本研究で構築した可変ゲインシステムに用いたニューラルネットワークの教師データは $t_r=20[\text{ms}]$ 、 $t_{cs}=40[\text{ms}]$ と固定し、 $\omega_{cs}=1000, 1500, 2000, 2500, 3000[\text{min}^{-1}]$ と変化させた場合の電流と回転速度である。

その例を図 5 に示す。

表 1 慣性負荷

Table 1 Inertial loads.

Load	Moment of inertia J [$\text{N}\cdot\text{m}\cdot\text{s}^2/\text{rad}$]
load1	1.37×10^{-5} (no load)
load2	6.85×10^{-5}
load3	13.7×10^{-5}
load4	10.3×10^{-5}




図 4 ニューラルネットワークの構造

Fig.4 Structure of the neural network.




図 5 教師データの例

Fig.5 Examples of teacher data.

5. ニューラルネットワークによる慣性モーメントのオンライン同定

前章で示したニューラルネットワークを用いて慣性モーメントの同定を行った。その結果を図 6 に示す。この図より、教師データ取得時と同じ負荷条件である load1~3 については高い同定精度が得られていることが分かる。

また、教師データ取得時と異なる負荷条件である load4 については文献 3)と同様に高い同定精度が得られていないことが分かる。これに関しては、load4 における同定値が学習した他の負荷である load2, 3 の付近に現れる傾向にあるため、学習させる負荷の値を細かく変化させることによって、学習させていない負荷の同定精度が改善できるのではないかと考えられる。

6. 可変ゲインシステムの構築

本研究では、4, 5 章で示したニューラルネットワークを用いて慣性モーメントの同定を行い、その値に応じて制御器のゲインを自動で調整するシステムの構築を行った。その際、簡単のために実験条件は、 $t_r=20[\text{ms}]$, $t_{cs}=40[\text{ms}]$, $\omega_{cs}=3000[\text{min}^{-1}]$ ($\theta_0=1080[\text{deg.}]$)という教師データ取得時と同様の位置指令のみを用いた。また、負荷に関しても学習させた load1~3 を用いることとする。

次に、本研究でのゲインの調整方法について説明する。本研究では、慣性モーメントの値をニューラルネットワークにより取得している。しかし、ニューラルネットワークから値が出力されるまで 40[ms]という時間を必要とする。よって、ゲインを変え

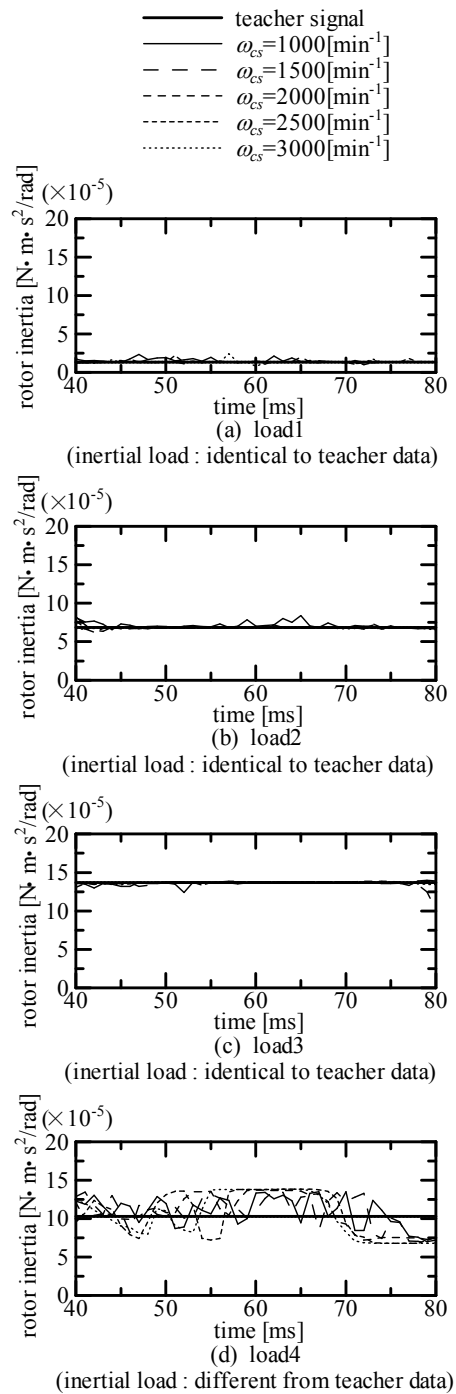


図 6 同定結果

Fig.6 Result of identification.

ることが出来るのは制御開始から 40[ms]後ということになる。また、ゲインを変えるのは制御開始からなるべく早いほうが良い

と考えられる。これより、ニューラルネットワークからの最初の出力 J_1 を用いてゲインを変えることとした。従って、制御開始から 40[ms]以前では第 3 章で示したゲインを使用し、40[ms]以降においてはゲインが慣性モーメントの値に応じて変化する。

また、本実験システムにおいて可変とするゲインについては、位置比例ゲイン K_{pp} 、速度比例ゲイン K_{sp} 、速度積分ゲイン K_{si} の 3 つがある。そして、このシステムにおいて速度制御系の開ループ伝達関数の周波数特性を用いた簡易な設計法を行うと、速度比例ゲイン K_{sp} 、速度積分ゲイン K_{si} が慣性モーメントに比例する⁷⁾。この簡易な設計法は速度制御器のゲインを求める際に面倒な計算をする必要が無いという特徴がある。また、速度比例ゲイン K_{sp} 、速度積分ゲイン K_{si} の 2 つを可変とするとゲイン調整が複雑になる。よって、本研究では速度比例ゲイン K_{sp} のみを調整することとした。位置比例ゲイン K_{pp} 、速度積分ゲイン K_{si} に関しては、第 3 章で示した値で固定とした。

そして、予備実験として次式に示す評価関数 I_{ea} の値が小さくなるように手で速度比例ゲイン K_{sp} を調整した。

$$I_{ea} = \int_0^{t_{\max}} |\theta(t) - \theta_r(t)| dt \quad (3)$$

この評価関数は目標値と実際の回転子角度の偏差の絶対値を時間積分したものであり、この値より制御期間全体における目標値追従性を定量的に評価できる。なお、本研究では $t_{\max}=500$ [ms] とした。慣性モーメントに対する速度比例ゲイン K_{sp} の変化を図 7 に示す。なお、load1 時のゲインの値は 3 章で示したものと同一である。

この結果より、速度比例ゲイン K_{sp} がほぼ




図 7 速度比例ゲインの変化

Fig.7 Variation of speed proportional gain.

線形的に変化していることが確認できる。これより、簡単のために速度比例ゲイン K_{sp} の変化を端の 2 点を結んだ直線で近似し、次のような式を構築した。

$$K_{sp} = 0.00147 \cdot J_1 + 0.00484 \quad (4)$$

この式を制御システムに組み込むことにより、ニューラルネットワークを用いてオンラインでゲインを自動調整するシステムを構築した。

7. 実験結果

前章で示したシステムを用いて位置制御を行った結果を図 8, 9 に示す。図 8, 9 より、制御期間中にゲインを変えることにより目標値追従性が改善されていることが分かる。なお、load1 についてはニューラルネットワークを用いたゲイン調整の前後で、ほぼ同じゲインの値を使用しているため目標値追従性に変化が生じていない。また、図 8(c)を見るとオーバーシュートよりアンダーシュートが大きく改善されている。これは、ゲインが変わるのは制御開始から 40[ms]後であるため、ゲイン変化後から時間がより経過しているアンダーシュートの方がゲインを変えたことによる効果が出ているためであると考えられる。

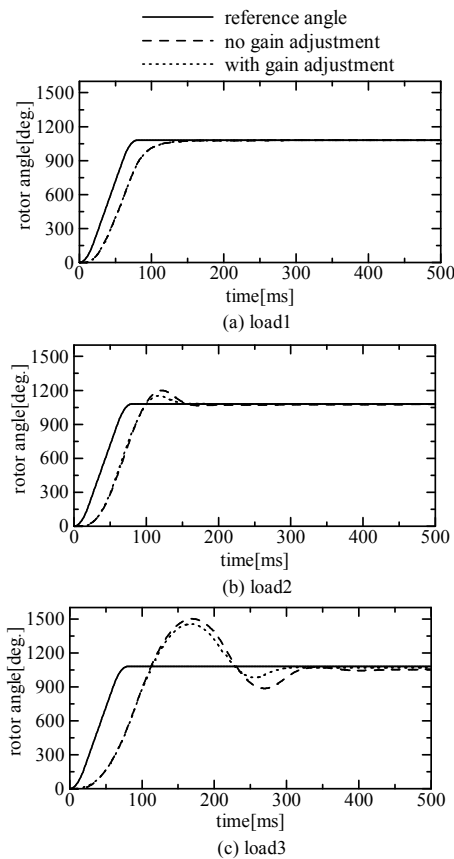


図 8 回転子角度の時間変化

Fig.8 Temporal variation of rotor angle.

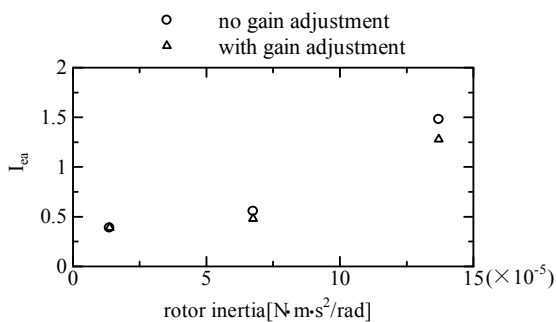


図 9 評価関数の変化

Fig.9 Variation of performance index.

また、ゲインを自動調整した際の慣性モーメントの同定結果を図 10 に示す。この図より、ゲインの調整前後でゲインの値が変わらない load1 に関しては同定値に変化が無いが、ゲインの値が変わる load2, 3 にお

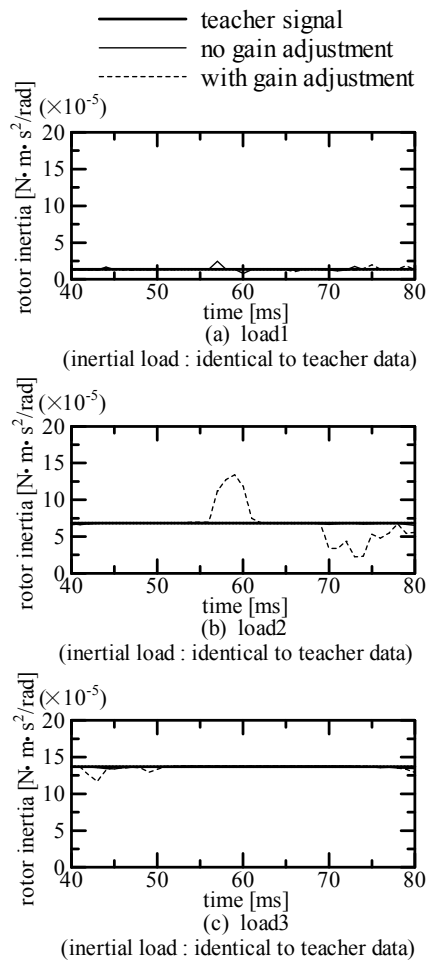


図 10 同定結果

Fig.10 Result of identification.

いては同定値も変化していることが確認できる。特に、load2 においては値が大きく変化している。これより、本手法のようにニューラルネットワークからの最初の出力である J_1 のみを用いてゲインを調整することは可能であるが、ニューラルネットワークからの出力に応じてゲインを逐次変化させることは困難であると考えられる。また、本手法の場合、使用する慣性モーメントの値は 1 つだけである。よって、ニューラルネットワークを現在用いている逐次同定ではなく、1 回のみ同定を行う単一同定に変

えることが考えられる。これは、単一同定は逐次同定と比べて学習に使用する教師データの数が少ないので、学習時間を短縮することが出来ると考えられるためである。

また、今回は負荷に関して学習させた load1~3 のみを用いて $\omega_{cs}=3000[\text{min}^{-1}]$ ($\theta_0=1080[\text{deg.}]$) の場合でしか検討していないため、他の駆動条件時に関して検討を行う必要がある。

8. おわりに

本研究では、ニューラルネットワークを用いて負荷の慣性モーメントの値を取得し、その値に応じて制御器のゲインを可変とするシステムの構築を行った。

ニューラルネットワークについては、学習させた負荷の同定精度は高いが、学習させていない負荷に関しては高い同定精度が得られなかった。これに関しては、学習させる負荷の値を細かく変化することにより改善できるのではないかと考えられる。

可変ゲインシステムについては、ニューラルネットワークからの出力に応じて制御器のゲインをオンラインで可変とするシステムを構築した結果、目標値追従性の改善が見られた。しかしながら、今回は負荷や位置指令について限られたパターンのみで実験を行っており、他の駆動条件時において検討を行う必要がある。また、ゲインを変えた影響で慣性モーメントの同定値が変化するため、ゲインを逐次変化させることは困難であると考えられる。

参考文献

- 1) 太田裕幸, 松尾健史, 三浦 武, 谷口敏幸, 米田 真: 回転子慣性の変動に対応したブラシレス DC モータの位置制御, 計測自動制御学会東北支部第 223 回研究集会, 223-11(2005)
- 2) 坂 圭介, 松尾健史, 秋山宜万, 三浦武, 谷口敏幸, 米田 真: 回転子慣性の変動に対応したブラシレス DC モータの位置制御その 2, 計測自動制御学会東北支部第 230 回研究集会, 230-4(2006)
- 3) 坂 圭介: ブラシレス DC モータ制御システムにおける慣性負荷のオンライン同定に関する研究, 秋田大学修士論文 (2007)
- 4) 大塚二郎: 位置決め制御技術の現状と動向, 計測と制御, 41, 11, 769/774(2002)
- 5) 三浦 武, 秋山宜万, 谷口敏幸: ステッピングモータ用ニューラルネットワーク形オブザーバ, 電気学会全国大会, 4-415, 1432(2001)
- 6) 馬場則夫, 小島史男, 小澤誠一: ニューラルネットワークの基礎と応用, 1/27, 共立出版(1994)
- 7) 杉本英彦, 小山正人, 玉井伸三: AC サーボシステムの理論と設計の実際, 153/179, 総合電子出版社(1990)